

# LUTTE CONTRE LE PHISHING

Revue de Littérature sur la Détection de Phishing

**Armand Florent TSAFACK PIUGIE**

TEICEE ET UNICAEN

Laboratoire GREYC

[ftsafack@teicee.com](mailto:ftsafack@teicee.com)

[armand-florent.tsafack-piugie@unicaen.fr](mailto:armand-florent.tsafack-piugie@unicaen.fr)



**GREYC**  
Electronics and Computer Science Laboratory



# Qui suis-je ?

**Nom** : Tsafack Piugie

**Prénom** : Armand Florent

**Adresses Mails**: [armand-florent.tsafack-piugie@unicaen.fr](mailto:armand-florent.tsafack-piugie@unicaen.fr) | [ftsafack@teicee.com](mailto:ftsafack@teicee.com)

**Tel** : 06 60 44 14 65

## Parcours Académique

- **2015-2016** : Baccalauréat Scientifique
- **2016-2019** : Licence en Physique option EEA
- **2019-2021** : Master of Sciences

## Parcours Professionnel

- **2021-2022** : Compétences en IA, Enseignement et chargé de TD
- **2022-2023** : Cours Réseau Neurones M2 Pro, Direction R&D et ML engineer à Agrix-Tech
- **Mars 2024** : Doctorant CIFRE 1ère année (**ANRT - teicée - GREYC** de l'**UCN**) en cybersécurité travaillant sur **la Lutte contre le Phishing en utilisant l'IA**.
- Au **GREYC**, je suis à l'équipe **SAFE** (**S**écurité **A**rchitecture **F**orensique **b**iom**E**trie)



## Encadrement de la thèse

### GREYC – Equipe SAFE

- Directeur de thèse : **Emmanuel Giguet**
- Co-directeur : **Christophe Rosenberger**

### téicée

- Responsable pôle R&D : **Mathieu Valois**
- Gérant : **Philippe Chauvat**

# Plan

1. Contexte
2. Problème
3. Objectifs : Général et spécifiques
4. Enjeux Scientifiques de la recherche
5. Plan de travail
6. État de l'art
7. Mes travaux durant ce premier semestre
8. Formations SYGAL suivies

# 1. Contexte

## ➤ La messagerie électronique

- En 2023, **121 Billions de mails échangés** entre **4.3 Billions de personnes** [XoMEDIA,2024]
- **~1.4 Milliards** de mails par jour sont envoyés en France [Corthesy,2022]
- **53% du trafic mondial des emails** sont des Spams et causent des pertes d'environ **20M USD**.
- Synoptique d'envoi d'un e-mail




Figure1 : Schéma de principe de la messagerie électronique [XoMEDIA, A Deep into Email Deliverability in 2024]

# 1. Contexte

## ➤ Les attaques de Phishing menacent les Organisations

### Données récentes

- ~91% de toutes les cyberattaques sont les attaques de Phishing par mail [TEHTRIS, 2024]
- ~50% des grandes organisations reçoivent en moyenne 5 e-mails de phishing ciblé par jour [TEHTRIS, 2024]
- Pour une entreprise, le coût moyen d'une attaque de phishing par mail réussie est d'environ 4,65M USD [L.Ana, 2024]

Les attaques de phishing sont rentables et, avec le temps, les attaquants affinent leurs méthodes pour gagner en crédibilité et augmenter leur nombre de victimes.



Figure2 : Evolution des attaques de phishing [N.Quang & Selamat ; avril 2022]

# 1. Contexte

## ➤ Définition d'une attaque de Phishing

- *Phreaking* : piratage de ligne téléphonique
- *Fishing* : pêche
- Contraction de *fishing* et *phreaking*




Schéma traduit et adapté de : [https://www.elie.net/blog/anti\\_fraud\\_and\\_abuse/how-phishing-works](https://www.elie.net/blog/anti_fraud_and_abuse/how-phishing-works)

Figure3 : Synoptique d'une attaque de phishing par mail [N.Quang & Selamat ; april 2022]




Figure4 : Techniques d'ingénieries sociales utilisées par les cyberattaquants pour lancer les attaques de phishing [N.Quang & Selamat ; april 2022]

# 1. Contexte

## ➤ Exemple n°1 de mail de phishing

## ➤ Exemple n°2 de mail de phishing

IT-Service desk : Coronavirus notice for all Matthijssen Business employees

ATTACHMENT: Contains malware

Williams, Sarah <s.william@nnattnj.com>  
Thu 3/26/2020 2:02 PM  
To: John Smith

COVID Staff Survey.pdf  
2.2 MB

Attn All staff, **TOO GENERIC**

**FAKE E-MAIL ADDRESS:** uses "nn" instead of "m"

**POOR GRAMMAR**

This is a ongoing outbreak of deadly virus called coronavirus (CoVID-19). The virus spreading like **wide fire** and the World Health Organization are doing everything possible to contain the current situation. The virus which originate in China has hit Europe, America, Asia and Africa. The government has hereby instructed all organization to **immediately** educate and enlightened their employees/staff about the virus in order to increase awareness of (CoVID19).

**URGENCY**

In view with the directives, the institution is currently organizing a seminar for all staff to talk about this deadly virus. All employee/staff **must participate** and will **each required** to complete a survey to show your awareness. A recording is provided for the seminar and all must register by end of work tomorrow. Disciplinary **measure** will be taken for staff that fails to complete this instruction. Winning this battle is our collective effort. Kindly follow the link **COVID SEMINAR** to register and **be counted as complete**.

Instructions for the staff survey is given as attachment in this instruction. We recommend all staff review the steps to make sure all complete this directive.

**BAD LINKS:**  
<http://66.165.152.168/nnattnj.com/covid119seminar/regis>

Best Regards,  
IT-Service desk  
support@nnattnj.com  
Matthijssen Business Systems

**LEGEND**

- FAKE E-MAIL ADDRESS
- TOO GENERIC
- BAD LINKS
- URGENCY
- SYNTAX & GRAMMATICAL ERRORS

Mark Mark mark.seotech@gmail.com [redacted] 07:33 (6 hours ago)

to info

Hi,  
**Website Administrator**

SEO is the best way to increase your business volume. And **we have an experts SEO team.**

We can quickly promote your website. We can place your website on top of the Natural Listings on Google, Yahoo and MSN.

- Position your website to be top-ranking
- Refine your website design to be engaging **Do what?**
- **Increase profitability click-through rates** from PPC campaigns
- Develop strong conversion rates
- Expert web statistics analysis **Bargain!**

Our prices are less than half of what other companies charge.

We would be happy to send you a proposal using the top search phrases for your area of expertise.

Note: - Please **must** check our past record and current clients status. **Must!? Ok then.**

**WE ALSO DESIGN & DEVELOPE** THE WEB-SITE FLASH PHP, Joomla, Open source, E-Commerce at reasonable cost.

Thanks & Regards **Less than 1/2 the cost of your competitors apparently**

**Mark**  
[mark.seotech@gmail.com](mailto:mark.seotech@gmail.com)  
SEO - Link Building - **Copyrighting** - Web Designing - PHP

**Are you shouting now?**

**I think you mean copywriting?**

## 2. Objectifs

**Concevoir un système de protection robuste et fiable contre les attaques de phishing avec la détection automatique et la modération par l'humain.**

- Analyser les différents aspects des attaques de type phishing ;
- Suivi des statistiques et faire une veille technologique sur l'évolution des escroqueries par phishing ;
- Proposer des solutions comme contre-mesures en utilisant un faisceau d'indices ;
- Utilisation des techniques d'IA basées sur le ML, le DL couplées aux méthodes de TAL ;
- Approche collaborative exploitant le résultat de l'analyse automatique et le signalement par un utilisateur (modérateurs DSI et ou RSSI pour confirmer ou infirmer le statut du mail) ;

# 3. Enjeux Scientifiques

- Mise au point d'une méthode performante par apprentissage permettant de décider si un mail contient une attaque de phishing;
- Création de partage d'un dataset ;
- Mécanisme d'anonymisation/pseudonymisation l'analyse manuelle d'un mail suspect et pour création de partage d'un dataset ;
- Définition d'une signature de quasi-similarité de mails pour la généralisation de la détection de mail de phishing personnalisé

# 5. Plan de Travail

- Réaliser un état de l'art de toutes les facettes de la lutte contre le phishing;
- Créer une base de mails de phishing spécialisée sur le français ;
- Analyser l'impact de l'anonymisation et de la pseudonymisation sur la détection du phishing, les mesures de protection de la vie privée avec l'identification des données en terme de DCP sensible ainsi que la conception de services innovants sécurisés suivant la réglementation RGPD ;
- Analyser la structure et du contenu des mails de phishing,
- Génération d'empreintes de documents permettant une recherche approximative dans des espaces de grande dimension ;
- Utilisation des modèles de ML et de DL pour la prédiction et la détection des attaques de phishing, etc

## 6. État de l'art



## 6.1. Revue des Bases de Données des mails de phishing

| Dataset   | Size                  | Parties de mail utilisées | Classe 1  | Classe 2                                 | créateur   | Lien téléchargement   |
|---|-----------------------|---------------------------|---|--|--|---|
| Phishing Archive (APWG)                             |                       | Body                      |   |  | Anti-Phishing Working Group                                    |   |
| Corpora of the SpamAssassin project                 | >9000                 | Body + Header             | Easy_ham and hard_ham (Apache Software Foundation (2014) Spamassassin Public Corpus, 2006) Easy ham_2 | Spam_3                                   |  | <a href="https://spamassassin.apache.org/downloads.html">https://spamassassin.apache.org/downloads.html</a>   |
| SpamAssassin containing and emails available online |                       | Body                      | 2551 ham  | 501 spam                                 |  | <a href="https://www.kaggle.com/datasets/veleon/ham-and-spam-dataset">https://www.kaggle.com/datasets/veleon/ham-and-spam-dataset</a>   |
| Enron   | >500,000              | Body                      | 43 000 ham  | 50,000 spam                              | CALO Project (A Cognitive Assistant that Learns and Organizes) | <b>Enron all</b> : <a href="http://www.cs.cmu.edu/~enron/enron_mail_20150507.tar.gz">http://www.cs.cmu.edu/~enron/enron_mail_20150507.tar.gz</a><br><b>Enron-Spam Dataset</b><br>- <b>Lien Original</b> : <a href="https://www2.aueb.gr/users/ion/data/enron-spam/">https://www2.aueb.gr/users/ion/data/enron-spam/</a><br>- <b>Version Prétraité</b> : <a href="https://github.com/MWiechmann/enron_spam_data/">https://github.com/MWiechmann/enron_spam_data/</a> |
| Enron1  | 6447                  | Body                      | 3228 ham  | 3219 spam emails                         |  | <a href="https://www2.aueb.gr/users/ion/data/enron-spam">https://www2.aueb.gr/users/ion/data/enron-spam</a>   |
| TREC corpus   |                       | Body                      | 39,399 legitimate emails  | 52,790 spam emails                       |  | <b>2007 TREC Public Spam Corpus</b><br><br><b>Version Originale</b> : <a href="https://plg.uwaterloo.ca/~gvcormac/treccorpus07/">https://plg.uwaterloo.ca/~gvcormac/treccorpus07/</a><br><b>Version prétraité</b> : <a href="https://www.kaggle.com/datasets/bayes2003/emails-for-spam-or-ham-classification-trec-2007">https://www.kaggle.com/datasets/bayes2003/emails-for-spam-or-ham-classification-trec-2007</a>   |
| CSDMC 2010 SPAM                                     | 4,327 training emails | Body + Header             | 2,949 ham   | 1378 spam                                | Organizers of data mining competition                          | <a href="https://github.com/jdwilson4/Intro-to-Machine-Learning/tree/master/Data/SPAMData">https://github.com/jdwilson4/Intro-to-Machine-Learning/tree/master/Data/SPAMData</a>   |
| Nazario/Phishing Corpus                             |                       |                           |   | 7315 spam                                | Jose Nazario   | <a href="https://monkey.org/~jose/phishing/">https://monkey.org/~jose/phishing/</a>   |
| SMS Spam Collection                                 | 5572                  |                           | 4825 ham  | 747 spam                                 | University of California irvine                                | <a href="https://www.kaggle.com/datasets/uciml/sms-spam-collection-dataset">https://www.kaggle.com/datasets/uciml/sms-spam-collection-dataset</a>   |
| IWSPA-AP-2018                                       | 10,306                | Body + Header             | 9174 ham  | 1132 spam                                | Organizers of IWSPA 2018 competition                           | <a href="https://dasavisha.github.io/IWSPA-sharedtask/">https://dasavisha.github.io/IWSPA-sharedtask/</a>   |
| live emails received by WestPac and their customer  | 659,673 emails        |                           | 613,048 emails are legitimate   | 46,525 of the emails are phishing emails |  |   |

## 6.2. Deep Learning Models for Phishing Email Detection

| Article Title  | year          | Authors  | Purpose                       | Source de Données   | Parts of Email used | Taxonomy of feature extraction used  | Models   | Precision | Accuracy  | Score f1                          |
|--|---------------|--|-------------------------------|---|---------------------|--|--|-----------|---|-----------------------------------|
| Advancing Phishing Email Detection : A Comparative Study of DL Models                                  | March 2024    | Najwa Altwijry, Isra Al-Turaiki, Reem Alotaibi and Fatimat Alakeel | Text Classification           | Phishing Corpus (7315 mail de phishing) and Spam Assassin (6047 email samples, in which there are 1897 spam emails and 4150 legitimate emails)  | Body and Subject    | GloVe  | 1D-CNNPD with recurrent layers namely LSTM, Bi-LSTM, GRU and Bi-GRU  |           | 98.87%, 99.23%, 99.34%, 99.01%, 99.68%,         | -, 99.20%, 99.31%, 99.66%, 99.66% |
| Phishing Email Detection Model Using Deep Learning   | October 2023  | Samer Atawneh and Hamzah Aljehani                                  | Phishing Email Detection      | <b>Enron, SpamAssassin et UCI</b> pour constituer un jeu de données de mails étiquetés ( <b>en mails légitimes et mails de phishing</b> ) de <b>18040</b> échantillons                      | Body                | Tokenization (Keras tonkenizer class for first 3 models and Hugging face tokenizer class for BERT wich use the WordPiece method) | CNN, RNN, LSTM, BERT   |           | 98.74%, 98.58%, 98.89%, 99.61%                  |                                   |
| Phishing Email Detection using improved RCNN with multilevel vectors and attention mechanism           | March 2019    | Yong Fang , Cheng Zhang, Cheng Huang , Liang liu, and Yue Yang     | Classifying Phishing Email    | First Security and Privacy Analytics Anti-Phishing Shared Task (IWSPA-AP 2018) : legitimate emails (Wikileaks), phishing emails (IT departments of university and Nazario Phishing corpora) | Subject and Body    | Word2Vect  | THEMIS that utilized an improved recurrent convoluntional neural network (RCNN) model with multilevel vectors and attention mechanisms |           | 99.848% and a low false-positive rate of 0.043% |                                   |
| Phishing and Fraudulent Email Detection through Transfer Learning using pretrained transformer models. | November 2022 | Bronjon Gogoi; Tasiruddin Ahmed                                    | Phishing email Classification |   |                     |  | BERT and DistilBERT  |           | 99%   |                                   |

## 6.3. Machine Learning Models for Phishing Email Detection

| Article Title  | year | Authors  | Purpose   | Data Sources   | Parts of Email used                              | Taxonomy of feature extraction used   | Models   | Precision | Accuracy  | Score f1                                  |
|--|------|--|---|--|--|---|--|-----------|---|---|
| Detecting Phishing Email Using Hybrid features                   | 2009 | Liping Ma, Bahadorrez da Ofoghi, Paul Watters, Simon Brown | Classifying phishing Email using Hybrid Features  | WestPac emails   | Subject, Body                                    | Links, nonv links, nonmatching urls, forms, scripts, body BL words, subject BL wors, Information Gain | C4.5   |           | 99%   |   |
| Phishing Email Detection Technique by using Hybrid Features      | 2015 | Isredza Rahmi A. Hamid and Jemal Abawajy                   | Binary classification problem   | Phishing Corpus and SpamAssassin (pour constitué un small training set of 1000 emails) |  | Collection of nine structure- and behavior-based features : DES, SBW, URLD, URLs, URLIP, US, UD, DMID | SVM  |           | 97.25%  |   |
| Accurate spear phishing campaign attribution and early detection | 2016 | YuFei Han  | semisupervised learning approach with a dataset of 1467 spearphishing emails and 4043 legitimate emails | Symantec's enterprise email scanning service   | origin, text, attachment, and recipient features |   | K-nearest neighbor attribute graph to detect spear phishing attacks  |           |   | 90% and an FPR of 0.1 for known campaigns |
| Spam Email Detection Using ML Techniques                         | 2023 | Ioannis Moutafis, Antonios Andreatos and Petros Stefaneas  | text classification   | Spam Assassin, Enron1, SMS-Spam Collection   | Body   |   | SVM, k-nearest neighbor, naïve Bayes, neural network, recurrent neural network, AdaBoost, random forest, gradient boosting, logistic regression, and decision tree methods |           | For the first dataset, the best performance was 99.51%, achieved by the NN, while the SVM achieved 99.38% for the second dataset. |   |

## **7- Mes Travaux au cours de ce 1er Semestre**

## 7- Mes Travaux au cours de ce 1er Semestre

- Entraînement de 11 modèles de ML et 1 modèle Deep sur la base constitué à partir des sources Enron et TREC 2007 (~83k échantillons étiquetés en spam et ham)

Tableau récapitulatif des performances des modèles de ML et DL







| Algorithmme | Accuracy     | Score f1    | Precision   |
|-------------|--------------|-------------|-------------|
| <b>ETC</b>  | <b>0.986</b> | <b>0.99</b> | <b>0.99</b> |
| RF          | 0.984        | 0.982       | 0.980       |
| LR          | 0.981        | 0.98        | 0.974       |
| BgC         | 0.972        | 0.97        | 0.97        |
| MNB         | 0.955        | 0.96        | 0.955       |
| GNB         | 0.960        | 0.96        | 0.957       |
| AdaBoost    | 0.947        | 0.95        | 0.95        |
| SVC         | 0.932        | 0.93        | 0.931       |
| KN          | 0.915        | 0.92        | 0.867       |
| DT          | 0.859        | 0.86        | 0.801       |
| NN          | 0.971        | -           | -           |
| DistilBERT  | 0.95         | 0.95        | -           |

Tableau récapitulatif des performances des modèles de ML réalisé par (Ioannis et al., 2023) sur 03 Datasets

| Algo/Dataset | SpamAssa sin  | Enron1        | csv by F.Qureshi |
|--------------|---------------|---------------|------------------|
| <b>SVM</b>   | <b>0.9918</b> | <b>0.9938</b> | <b>0.9839</b>    |
| KNN          | 0.959         | 0.9853        | 0.9551           |
| NB           | 0.9131        | 0.983         | 0.9543           |
| NN           | 0.9951        | 0.9922        | 0.9823           |
| RNN          | 0.9836        | 0.993         | 0.983            |
| AB           | 0.982         | 0.983         | 0.9838           |
| RF           | 0.982         | 0.972         | 0.9811           |
| GB           | 0.959         | 0.966         | 0.959            |
| LR           | 0.9541        | 0.9922        | 0.965            |
| DT           | 0.9573        | 0.965         | 0.9786           |

# 7- Mes Travaux au cours de ce 1er Semestre

- École d'été sur la cybersécurité organisée par l'ENSICAEN : J'ai travaillé sur le projet de técicée notamment sur l'analyse forensique de la base de données d'Enron



## 8- Formations suivies

### Formations SYGAL

- Logiciel d'Apprentissage Automatique (**10h**)
- Comment faire confiance à l'Intelligence Artificielle : une introduction à l'IA de confiance (**03h**)
- Travail collaboratif et gestion de versions avec Git (**06h**)
- Comment faire confiance à l'Intelligence Artificielle : les différents ingrédients de l'IA de confiance (**04h**)

### Formation ANRT

- Horizon Europe pour les jeunes chercheurs : A la découverte de opportunités de financement et des politiques de recherche (**4h**)

# Conclusion

Tout comme les attaques de phishing par mails sont de plus en plus rentables (puisque les attaquants affinent leurs méthodes avec les techniques d'ingénieries sociales), les solutions de détections sont aussi croissantes (de part les architectures développées et entraînées dans la revue). Ce pendant, la difficulté d'avoir des jeux de données étiquetés et sans biais limite la capacité de généralisation des solutions existantes. D'où la pertinence et les enjeux de cette thèse.

**Merci !**